# WELTORGANISATION FÜR GEISTIGES EIGENTUM Internationales Büro

## INTERNATIONALE ANMELDUNG VERÖFFENTLICHT NACH DEM VERTRAG ÜBER DIE INTERNATIONALE ZUSAMMENARBEIT AUF DEM GEBIET DES PATENTWESENS (PCT)

(51) Internationale Patentklassifikation 6:

H04S 1/00, H04R 29/00

(11) Internationale Veröffentlichungsnummer:

WO 98/23130

A1

(43) Internationales Veröffentlichungsdatum:

28. Mai 1998 (28.05.98)

(21) Internationales Aktenzeichen:

PCT/EP97/05446

(22) Internationales Anmeldedatum: 2. Oktober 1997 (02.10.97)

US, europäisches Patent (AT, BE, CH, DE, DK, ES, FI, FR, GB, GR, IE, IT, LU, MC, NL, PT, SE).

(30) Prioritätsdaten:

196 47 399.3

15. November 1996 (15.11.96) DE

Veröffentlicht

Mit internationalem Recherchenbericht.

(81) Bestimmungsstaaten: AU, CA, CN, JP, KR, NO, RU, UA,

(71) Anmelder (für alle Bestimmungsstaaten ausser US): FRAUN-HOFER-GESELLSCHAFT ZUR FÖRDERUNG DER ANGEWANDTEN FORSCHUNG E.V. [DE/DE]; Leonrodstraße 54, D-80636 München (DE).

(72) Erfinder; und

(75) Erfinder/Anmelder (nur für US): SEITZER, Dieter [DE/DE]; Humboldtstraße 14, D-91054 Erlangen (DE). SPORER, Thomas [DE/DE]; Wilhelmshavener Straße 15, D-90766 Furth (DE).

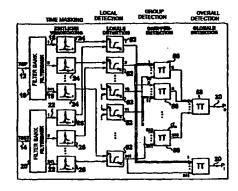
(74) Anwalt: SCHOPPE, Fritz; Postfach 71 08 67, D-81458 München (DE).

(54) Title: HEARING-ADAPTED QUALITY ASSESSMENT OF AUDIO SIGNALS

(54) Bezeichnung: GEHÖRANGEPASSTE QUALITÄTSBEURTEILUNG VON AUDIOSIGNALEN

#### (57) Abstract

In a method for assessing the quality of an audio test signal (14), which has been derived by coding and decoding an audio reference signal (12), the audio test signal (14) is compared with the audio reference signal (12), as it were, behind the cochlea of the human ear. All masking effects and the transmission functions of the ear are equally applied to the audio reference signal (12) and to the audio test signal (14). To this end, the audio test signal (14) is broken down according to its spectral components by means of a first bank of filters (20) consisting of filters overlapping in frequency and defining spectral regions, said filters having differing filtering functions, which have been determined on the basis of the excitation curve of the human ear with respect to the respective filtered middle frequency. The audio reference signal (12) is also broken down according to its spectral composition into partial audio reference signals by means of a second bank of filters (16) coinciding with the first bank of filters (2). Subsequently, a level difference by spectral region is formed between the audio test signals (22) belonging to the same spectral regions and the audio



reference signals (18). To assess the quality of the audio test signal (14), a detection probability is determined on the basis of each level difference so as to pick up any decoding error of the test signal (14) in the spectral region concerned.

#### (57) Zusammenfassung

Bei einem Verfahren zur Qualitätsbeurteilung eines Audiotestsignals (14), das durch Codierung und Decodierung von einem Audioreferenzsignals (12) abgeleitet ist, findet ein Vergleich des Audiotestsignals (14) mit dem Audioreferenzsignal (12) gewissermaßen hinter der Gehörschnecke des menschlichen Ohrs statt. Alle Verdeckungseffekte sowie die Übertragungsfunktion des Ohrs werden gleichermaßen auf das Audioreferenzsignal (12) und das Audiotestsignal (14) angewandt. Dazu wird das Audiotestsignal (14) gemäß seiner spektralen Zusammensetzung mittels einer ersten Filterbank (20) aus einander sich frequenznäßig überlappenden, Spektralabschnitte definierenden Filtern mit voneinander abweichenden Filterfunktionen zerlegt, die jeweils aufgrund der Erregungskurven des menschlichen Ohrs bei der jeweiligen Filtermittenfrequenz festgelegt sind. Das Audioreferenzsignal (12) wird ebenfalls gemäß seiner spektralen Zusammensetzung mittels einer mit der ersten Filterbank (20) übereinstimmenden zweiten Filterbank (16) in Audioreferenzteilsignale (18) zerlegt. Anschließen den zu gleichen Spektralabschnitten gehörigen Audiotestteilsignalen (22) und Audioreferenzteilsignalen (18) gebildet. Zur Qualitätsbeurteilung des Audiotestsignals (14) wird spektralabschnittsweise eine Detektionswahrscheinlichkeit für die Erfassung eines Codierungsfehlers des Audiotestsignals (14) in dem betreffenden Spektralabschnitt aufgrund der jeweiligen Pegeldifferenz bestimmt.

#### LEDIGLICH ZUR INFORMATION

Codes zur Identifizierung von PCT-Vertragsstaaten auf den Kopfbögen der Schriften, die internationale Anmeldungen gemäss dem PCT veröffentlichen.

AL	Albanien	RS	Spanien	LS	Lesotho	SI	Slowenica
AM	Armenien	FI	Finnland	LT	Litauen	SK	Slowakei
AT	Österreich	FR	Frankreich	LU	Luxemburg	SN	Senegal
ΑU	Australien	GA	Gabun	LV	Lettland	SZ	Swasiland
AZ	Aserbaidschan	GB	Vereinigtes Königreich	MC	Monaco	170	Tschad
BA	Bosnien-Herzegowina	GB	Georgien	MD	Republik Moldau	TG	Togo
BB	Barbados	GH	Ghana	MG	Madagaskar	TJ	Tadschikistan
BE	Belgien	GN	Guinea	MK	Die ehemalige jugoslawische	TM	Turkmenistan
BF	Burkina Faso	GR	Griechenland		Republik Mazedonien	TR	Türkei
BG	Bulgarien	HU	Ungarn	ML	Mali	TT	Trinidad und Tobago
BJ	Benin	IE	Irland	MN	Mongolei	UA	Ukraine
BR	Brasilien	IL	Israel	MR	Mauretanien	UG	Uganda
BY	Belarus	IS	Island	MW	Malawi	us	Vereinigte Staaten von
CA	Kanada	ΙŦ	Italien	MX	Mexiko		Amerika
CF	Zentralafrikanische Republik	JP	Japan	NE	Niger	UZ	Usbekistan
CG	Kongo	KE	Kenia	NL	Niederlande	VN	Vietnam
CH	Schweiz	KG	Kirgisistan	NO	Norwegen	YU	Jugoslawien
CI	Côte d'Ivoire	KP	Demokratische Volksrepublik	NZ	Neusceland	ZW	Zimbabwe
CM	Kamerun		Korea	PL	Polen		
CN	China	KR	Republik Korea	PT	Portugal		
CU	Kuba	KZ	Kasachstan	RO	Ruminien		
CZ	Tschechische Republik	LC	St. Lucia	RU	Russische Föderation		
DE	Deutschland	L	Liechtenstein	SD	Sudan		
DK	Dänemark	LK	Sri Lanka	SE	Schweden		
EE	Estland	LR	Liberia	SG	Singapur		

# Gehörangepaßte Qualitätsbeurteilung von Audiosignalen

### Beschreibung

Die vorliegende Erfindung bezieht sich auf die Audio-Codierung bzw. -Decodierung und insbesondere auf ein Verfahren und eine Vorrichtung zur gehörangepaßten Qualitätsbeurteilung von Audiosignalen.

Nachdem gehörangepaßte digitale Codierverfahren seit einigen Jahren standardisiert sind (Kh. Brandenburg und G. Stoll, The iso/mpeg-audio codec: A generic standard for coding of high quality digital audio, 92nd AES-Convention, Wien, 1992, Preprint 3336), werden dieselben in steigendem Maße eingesetzt. Beispiele hierfür sind die digitale Kompaktkassette (DCC; DCC = Digital Compact Cassette), die Minidisk, der digitale terrestrische Rundfunk (DAB; DAB = Digital Audio Broadcasting) und die digitale Videodisk (DVD). Die von analogen Übertragungen bekannten Störungen treten bei der digitalen uncodierten Tonsignalübertragung in der Regel nicht mehr auf. Die Meßtechnik kann sich auf den Übergang von analog zu digital und umgekehrt beschränken, falls keine Codierung der Tonsignale durchgeführt wird.

Bei der Codierung mittels gehörangepaßter Codierverfahren können jedoch hörbare Kunstprodukte oder Artefakte auftreten, die in der analogen Tonsignalverarbeitung nicht aufgetreten sind.

Bekannte Meßwerte für Verzerrungen, wie z.B. der Klirrfaktor oder der Signal-Rausch-Abstand, sind für gehörangepaßte Codierverfahren nicht einsetzbar. Viele gehörangepaßt codierte Musiksignale weisen einen Signal-Rausch-Abstand von unter 15 dB auf, ohne daß hörbare Unterschiede zum uncodierten Originalsignal wahrnehmbar werden. Umgekehrt kann ein Signal-Rausch-Abstand von mehr als 40 dB bereits zu deutlich hörbaren Störungen führen.

In den letzten Jahren wurden verschiedene gehörangepaßte Meßverfahren vorgestellt, von denen das NMR-Verfahren (NMR = Noise to Mask Ratio) erwähnt sei (Kh. Brandenburg und Th. Sporer. "NMR" und "Masking Flag": Evaluation of quality using perceptual criteria. In Proceedings of the 11th International Conference of the AES, Portland, 1992).

Bei einer Implementation des NMR-Verfahrens wird jeweils eine diskrete Fourier-Transformation der Länge 1024 unter Verwendung eines Hann-Fensters mit einer Fortschrittsgeschwindigkeit von 512 Abtastwerten für ein Originalsignal und für ein Differenzsignal zwischen dem Originalsignal und einem verarbeiteten Signal berechnet. Die daraus erhaltenen Spektralkoeffizienten werden in Frequenzbändern, deren Breite näherungsweise den von Zwicker in E. Zwicker, Psychoakustik, Springer-Verlag, Berlin Heidelberg New York, 1982, vorgeschlagenen Frequenzgruppen entspricht, zusammengefaßt, wonach die Energiedichte jedes Frequenzbandes bestimmt wird. Aus den Energiedichten des Originalsignals wird unter Berücksichtigung der Verdeckung innerhalb der jeweiligen Frequenzgruppe, der Verdeckung zwischen den Frequenzgruppen und der Nachverdeckung für jedes Frequenzband eine aktuelle Maskierungs- oder Verdeckungsschwelle bestimmt, mit der die Energiedichte des Differenzsignals verglichen wird. Die Ruhehörschwelle des menschlichen Ohrs wird nicht vollständig berücksichtigt, da die Eingangssignale des Meßverfahrens nicht mit festen Abhörlautstärken identifiziert werden können, da üblicherweise ein Hörer von Audiosignalen einen Zugriff auf die Lautstärke des Musik- oder Tonstücks hat, das er hören möchte.

Es hat sich herausgestellt, daß das NMR-Verfahren beispielsweise bei einer typischen Abtastrate von 44,1 kHz eine Frequenzauflösung von ca. 43 Hz und eine Zeitauflösung von ca. 23 ms besitzt. Die Frequenzauflösung ist bei niedrigen Frequenzen zu gering, während die Zeitauflösung bei hohen Frequenzen zu gering ist. Trotzdem reagiert das NMR-Verfahren

auf viele Zeiteffekte gut. Ist eine Folge von Anschlägen, wie z.B. Trommelschlägen, niedrig genug, dann hat der Block vor dem Anschlag noch eine sehr kleine Energie, wodurch ein eventuell auftretendes Vorecho genau erkannt werden kann. Die Fortschrittsgeschwindigkeit von 11,6 ms für das Analysefenster ermöglicht es, viele Vorechos zu erkennen. Liegt das Analysefenster allerdings ungünstig, so kann ein Vorecho unerkannt bleiben.

Der Unterschied zwischen einer Verdeckung durch tonale Signale und durch Rauschen wird bei dem NMR-Verfahren nicht berücksichtigt. Die verwendeten Verdeckungskurven sind aus subjektiven Hörtests gewonnene Erfahrungswerte. Die Frequenzgruppen sitzen dabei an festen Positionen innerhalb des Frequenzspektrums, wohingegen das Ohr die Frequenzgruppen dynamisch um einzelne besonders hervorstechende Schallereignisse im Spektrum bildet. Richtiger wäre daher eine dynamische Anordnung um die Energiedichteschwerpunkte. Durch die Breite der festen Frequenzgruppen ist es nicht möglich, zu unterscheiden, ob beispielsweise ein Sinus-Signal in der Mitte oder an einer Flanke einer Frequenzgruppe liegt. Die Verdeckungs- oder Maskierungskurve geht daher vom kritischsten Fall, d.h. der geringsten Verdeckung, aus. Das NMR-Verfahren zeigt deshalb manchmal Störungen an, die von einem Menschen nicht gehört werden können.

Die bereits erwähnte geringe Frequenzauflösung von lediglich 43 Hz stellt insbesondere im unteren Frequenzbereich eine Grenze für eine gehörangepaßte Qualitätsbeurteilung von Audiosignalen mittels des NMR-Verfahrens dar. Dies wirkt sich besonders nachteilig bei der Beurteilung von tiefen Sprachsignalen, wie sie beispielsweise ein männlicher Sprecher erzeugt, oder von Tönen sehr tiefer Instrumente, wie z.B. eine Baßposaune, aus.

Zum besseren Verständnis der vorliegenden Erfindung werden im nachfolgenden einige wichtige psychoakustische und kognitive Grundlagen für die gehörangepaßte Qualitätsbeurteilung

von Audiosignalen genannt. Der für die gehörangepaßte Codierung und Meßtechnik wichtigste Begriff ist die Verdeckung, welche in Anlehnung an den englischen Begriff "masking" auch oft Maskierung genannt wird. Ein leises einzeln auftretendes wahrnehmbares Schallereignis wird durch ein lauteres Schallereignis verdeckt, d.h. es wird in Anwesenheit des zweiten, lauteren Schallereignisses nicht mehr wahrgenommen. Die Verdeckung ist sowohl von der zeitlichen als auch der spektralen Struktur des Maskierers (d.h. des verdeckenden Signals) und dem verdeckten Signal abhängig.

Fig. 1 soll die Verdeckung von Tönen durch Schmalbandrauschsignale 1, 2, 3 bei 250 Hz, 1.000 Hz und 4.000 Hz und einem Schalldruckpegel von 60 dB veranschaulichen. Fig. 1 ist aus E. Zwicker und H. Fastl, Zur Abhängigkeit der Nachverdeckung von Störimpulsdauer, Acustica, Bd. 26, S. 78 - 82, 1972, entnommen.

Das menschliche Ohr kann dabei als eine Filterbank bestehend aus einer großen Zahl einander überlappender Bandpaßfilter betrachtet werden. Die Verteilung dieser Filter über der Frequenz ist nicht konstant. Insbesondere ist bei tiefen Frequenzen die Frequenzauflösung deutlich besser als bei hohen Frequenzen. Betrachtet man den kleinsten wahrnehmbaren Frequenzunterschied, so beträgt dieser unterhalb von ca. 500 Hz etwa 3 Hz und steigt oberhalb von 500 Hz proportional zur Frequenz oder Mittenfrequenz der Frequenzgruppen an. Ordnet man die kleinsten wahrnehmbaren Unterschiede nebeneinander auf der Frequenzskala an, so erhält man 640 wahrnehmbare Stufen. Eine Frequenzskala, die der menschlichen Frequenzempfindung angepaßt ist, stellt die Bark-Skala dar. Sie unterteilt den gesamten Hörbereich bis ca 15,5 kHz in 24 Abschnitte.

Aufgrund der Überlappung von Filtern endlicher Steilheit werden leise Tonsignale in der Nachbarschaft von lauten Tonsignalen maskiert. So werden in Fig. 1 alle unterhalb der eingezeichneten Schmalbandrauschkurven 1, 2, 3 vorhandenen

Sinustonsignale, welche im Spektrum als einzelne Linie dargestellt werden, verdeckt, wodurch sie nicht hörbar sind.

Die Flankensteilheit der einzelnen Verdeckungsfilter der modellmäßig angenommenen Filterbank im menschlichen Ohr ist ferner vom Schalldruckpegel des gehörten Signals und in geringem Maße von der Mittenfrequenz des jeweiligen Bandfilters abhängig. Die maximale Verdeckung hängt von der Struktur des Maskierers ab und beträgt bei der Verdeckung durch Rauschen ca. -5 dB. Bei der Verdeckung durch Sinustöne ist die maximale Verdeckung deutlich geringer und beträgt abhängig von der Mittenfrequenz -14 bis -35 dB (siehe in M.R. Schroeder, B.S. Atal und J.L. Hall, Optimizing digital speech coders by exploiting masking properties of the human ear, The Journal of the Acoustic Society of America, Bd. 66 (Nr. 6), S. 1647 - 1652, Dezember 1979).

Der zweite wichtige Effekt ist die Verdeckung im Zeitbereich, zu deren Verständnis Fig. 2 beitragen soll. Unmittelbar nach, aber auch unmittelbar vor einem lauten Schallereignis werden leisere Schallereignisse nicht wahrgenommen. Die zeitliche Verdeckung ist stark von der Struktur und Dauer des Maskierers abhängig (siehe H. Fastl, Mithörschwellen als Maß für das zeitliche und spektrale Auflösungsvermögen des Gehörs. Dissertation, Fakultät für Maschinenwesen und Elektrotechnik der Technischen Universität München, München, Mai 1974). Die Nachverdeckung kann sich insbesondere bis zu 100 ms erstrecken. Die größte Empfindlichkeit und damit die kürzeste Verdeckung tritt bei der Maskierung von Rauschen durch Gauß-Impulse auf. Hierbei betragen die Vor- und die Nachverdeckung lediglich etwa 2 ms.

Bei genügend großem Abstand vom Maskierer bzw. von 4 in Fig. 1 gehen die Maskierungskurven in eine Ruhehörschwelle 5 über. Am Beginn und Ende eines Verdeckungssignals gehen die Maskierungskurven der Vorverdeckung 6 bzw. der Nachverdeckung 7 in eine gleichzeitige Verdeckung 8 über. Fig. 2 ist im wesentlichen aus E. Zwicker, Psychoakustik, Sprin-

ger-Verlag, Berlin Heidelberg New York, 1982, entnommen.

Die Vorverdeckung wird durch die unterschiedlich schnelle Verarbeitung von Signalen auf dem Weg vom Ohr zum Gehirn bzw. im Gehirn erklärt. Große Reize, d.h. laute Schallereignisse oder Schallereignisse mit einem hohen Schalldruckpegel (SPL; SPL = Sound Pressure Level), werden schneller weitergegeben als kleine. Ein lautes Schallereignis kann deshalb ein zeitlich davorliegendes leiseres Schallereignis gewissermaßen "überholen" und damit verdecken.

Die Nachverdeckung entspricht einer "Erholungszeit" der Schallrezeptoren und der Reizleitung, wobei insbesondere der Abbau von Botenstoffen an den Nervensynapsen zu nennen wäre.

Das Verdeckungsmaß oder der Grad der Verdeckung hängt von der zeitlichen und spektralen Struktur des Maskierers, d.h. des maskierenden Signals, ab. Die Vorverdeckung ist bei impulsartigen Maskierern am kürzesten (etwa 1,5 ms) und bei Rauschsignalen deutlich länger (bis zu 15 ms). Die Nachverdeckung erreicht nach 100 ms die Ruhehörschwelle. Über die genaue Form der Nachverdeckungskurve finden sich unterschiedliche Aussagen in der Literatur. So kann im Einzelfall die Nachverdeckung bei Rauschsignalen zwischen 15 bis 40 ms differieren. Die oben angegebenen Werte stellen jeweils Minimalwerte für Rauschen dar. Neue Untersuchungen mit Gauß-Impulsen als Maskierer zeigen, daß für solche Signale auch die Nachverdeckung im Bereich von 1,5 ms liegt (J. Spille, Messung der Vor- und Nachverdeckung bei Impulsen unter kritischen Bedingungen, Internal Report, Thomson Consumer Electronics, Hannover, 1992). Werden sowohl Maskierer als auch Störsignale mittels eines Tiefpasses bandbegrenzt, so verlängern sich sowohl die Vor- als auch die Nachverdeckung.

Die zeitliche Verdeckung spielt bei der Beurteilung von Audiocodierverfahren eine wichtige Rolle. Wird, wie es meistens der Fall ist, blockweise gearbeitet, und befinden sich Anschläge im Block, so entstehen unter Umständen Störungen

vor dem Anschlag, die über dem Nutzsignalpegel liegen. Diese Störungen werden eventuell durch eine Vorverdeckung maskiert. Ist diese Störung jedoch nicht maskiert, so nennt man den entstehenden Effekt "Vorecho". Vorechos werden in der Regel nicht getrennt vom Anschlag wahrgenommen, sondern als eine tonmäßige Verfärbung des Anschlags.

Die Ruhehörschwelle (4 in Fig. 1) ergibt sich durch den Frequenzgang von Außen- und Mittelohr und durch die Überlagerung der ins Innenohr gelangten Schallsignale mit dem beispielsweise durch die Blutströmung verursachten Grundrauschen. Dieses Grundrauschen und die im Frequenzbereich nicht konstante Ruhehörschwelle verdecken dadurch sehr leise Schallereignisse. Aus Fig. 1 ist insbesondere zu sehen, daß ein gutes Gehör etwa einen Frequenzbereich von 20 Hz bis 18 kHz erfassen kann.

Die subjektiv empfundene Lautheit eines Signals hängt sehr stark von seiner spektralen und zeitlichen Zusammensetzung ab. Anteile eines Signals können andere Anteile desselben Signals verdecken, derart, daß diese nicht mehr zum Höreindruck beitragen. Signale nahe der Mithörschwelle (d.h. gerade eben noch wahrnehmbare Signale) werden als leiser empfunden als es ihrem tatsächlichen Schalldruckpegel entspricht. Dieser Effekt wird als "Drosselung" bezeichnet (E. Zwicker und R. Feldtkeller, Das Ohr als Nachrichtenempfänger, Hirzel-Verlag, Stuttgart, 1967).

Ferner spielen kognitive Effekte bei der Beurteilung von Audiosignalen eine Rolle. Insbesondere hat sich eine fünfstufige sog. "Impairmentskala" (Impairment = Beeinträchtigung) verbreitet. Die Aufgabe von menschlichen Testpersonen ist es, in einem Doppelblindtest Bewertungen für zwei Signale abzugeben, von denen eines das Originalsignal ist, das nicht codiert und decodiert worden ist, während das andere Signal ein nach einer Codierung und darauffolgenden Decodierung gewonnenes Signal ist. Bei dem Hörtest existieren drei Stimuli A, B, C, wobei das Signal A immer das Referenzsignal

ist. Eine Person, die den Hörtest durchführt, vergleicht immer die Signale B und C mit A. Das uncodierte Signal wird dabei als Referenzsignal bezeichnet, während das durch Codierung und Decodierung von dem Referenzsignal abgeleitete Signal als Testsignal bezeichnet wird. Bei der Bewertung von deutlich hörbaren Störungen spielen also nicht nur psychoakustische Effekte sondern auch kognitive oder subjektive Effekte eine Rolle.

Bei der Beurteilung von Audiosignalen durch menschliche Hörer haben kognitive Effekte erhebliche Auswirkungen auf die Bewertung mittels der Impairmentskala. Einzelne sehr starke Störungen werden von vielen Testpersonen vielfach als weniger störend als dauerhaft vorhandene Störungen empfunden. Ab einer bestimmten Anzahl solcher starken Störungen dominieren sie allerdings doch den Qualitätseindruck. Systematische Untersuchungen hierzu sind aus der Literatur nicht bekannt.

Obwohl sich bei psychoakustischen Test die Wahrnehmungsschwellen verschiedener Hörer kaum unterscheiden, werden verschiedene Artefakte von verschiedenen Testpersonen als unterschiedlich schwerwiegend empfunden. Während manche Testpersonen Beschränkungen der Bandbreite als weniger störend empfinden als Rauschmodulationen bei hohen Frequenzen, ist dies bei anderen Testpersonen genau umgekehrt.

Die Bewertungsskalen verschiedener Testpersonen unterscheiden sich deutlich. Viele Hörer tendieren dazu, deutlich hörbare Störungen mit der Note 1 ("sehr störend") zu bewerten, während sie mittlere Noten kaum vergeben. Andere Hörer vergeben häufig mittlere Noten (Thomas Sporer, Evaluating small impairments with the mean opinion scale – reliable or just a guess? In 101nd AES-Convention, Los Angeles, 1996, Preprint).

Die DE 44 37 287 C2 offenbart ein Verfahren zur Messung der Erhaltung stereophoner Audiosignale und Verfahren zur Erkennung gemeinsam codierter stereophoner Audiosignale. Ein

zu testendes Signal mit zwei Stereokanälen wird durch Codierung und anschließende Decodierung eines Referenzsignals
gebildet. Sowohl das zu testende Signal als auch das Referenzsignal werden in den Frequenzbereich transformiert. Für
jedes Teilband des Referenzsignals und für jedes Teilband
des zu testenden Signals werden Signalkenngrößen für das
Referenzsignal und für das zu testende Signal gebildet. Die
jeweils zu demselben Teilband gehörenden Signalkenngrößen
werden miteinander verglichen. Aus diesem Vergleich wird auf
die Erhaltung stereophoner Audiosignaleigenschaften oder die
störung des Stereoklangbilds bei der verwendeten Codierungstechnik geschlossen. Subjektive Einflüsse auf das Referenzsignal und auf das zu testende Signal aufgrund der Übertragungseigenschaften des menschlichen Ohrs werden in dieser
Schrift nicht berücksichtigt.

Die Aufgabe der vorliegenden Erfindung besteht darin, ein Verfahren und eine Vorrichtung für eine gehörangepaßte Qualitätsbeurteilung von Audiosignalen zu schaffen, welche durch eine verbesserte zeitliche Auflösung eine bessere Modellierung der Vorgänge im menschlichen Gehör erreichen, um von subjektiven Einflüssen unabhängiger zu werden.

Diese Aufgabe wird durch ein Verfahren gemäß Anspruch 1 und durch eine Vorrichtung gemäß Anspruch 18 gelöst.

Der Erfindung liegt die Erkenntnis zugrunde, alle nichtlinearen Gehöreffekte auf das Referenzsignal und das Testsignal gleichermaßen zu simulieren, und einen Vergleich zur Qualitätsbeurteilung des Testsignals sozusagen hinter dem Ohr, d.h. am Übergang der Gehörschnecke zum Gehörnerv, durchzuführen. Die gehörangepaßte Qualitätsbeurteilung von Audiosignalen arbeitet also mittels eines Vergleichs in dem Gehörschneckenbereich ("Cochlear Domain"). Es werden also die Erregungen im Ohr durch das Testsignal bzw. durch das Referenzsignal verglichen. Dazu werden sowohl das Audioreferenzsignal als auch das Audiotestsignal durch eine Filterbank in ihre spektralen Zusammensetzungen zerlegt. Durch ei-

ne große Anzahl von Filtern, welche sich frequenzmäßig überlappen, wird eine ausreichende sowohl zeitliche aus auch frequenzmäßige Auflösung sichergestellt. Die Gehöreffekte des Ohrs werden derart berücksichtigt, daß jedes einzelne Filter eine eigene Form aufweist, die anhand der Außen- und Mittelohr-übertragungsfunktion und des internen Rauschens im Ohr, anhand der Mittenfrequenz  $f_m$  eines Filters und anhand des Schalldruckpegels L des zu beurteilenden Audiosignals bestimmt wird. Zur Reduzierung der Komplexität und des Rechenaufwands wird für jede Filterübertragungsfunktion eine Betrachtung des schlimmstmöglichen Falles durchgeführt, wodurch eine sog. Worst-Case-Erregungskurve für verschiedene Schalldruckpegel bei der jeweiligen Mittenfrequenz jedes Filters für dasselbe bestimmt wird.

Zur weiteren Reduzierung des Rechenaufwands werden Teile der Filterbank mit verringerter Abtastrate berechnet, wodurch der zu verarbeitende Datenstrom entscheidend reduziert wird. Aus Kompatibilitätsgründen mit der schnellen Fourier-Transformation oder Abwandlungen derselben, welche durch die Filterbank ausgeführt wird, werden lediglich Abtastraten verwendet, die sich durch den Quotienten aus der Ursprungsabtastrate und einer Potenz von 2 (d.h. das 1/2-, das 1/4-, das 1/8-, das 1/16-, das 1/32-fache der ursprünglichen Abtast- bzw. Datenrate) ergeben. So wird immer eine einheitliche Fensterlänge der verschiedenen Filtergruppen, die mit einer gleichen Abtastfrequenz arbeiten, erreicht.

Schließlich ist jedem Filter der Filterbank eine Modellierungseinrichtung zum Modellieren der Vor- und Nachverdeckung nachgeschaltet. Die Modellierung der Vor- und Nachverdeckung verringert die erforderliche Bandbreite so weit, daß je nach Filter eine weitere Reduktion der Abtastrate, d.h. eine Unterabtastung, möglich ist. Die resultierende Abtastrate in allen Filtern entspricht somit bei einem bevorzugten Ausführungsbeispiel der Erfindung einem zweiunddreißigstel der Eingangsdatenrate. Diese gemeinsame Abtastrate für alle Filterbänke ist für die weitere Verarbeitung äußerst vorteil-

halft und nötig.

Nach der Filterbank erfolgt die Bestimmung der Verzögerung der Ausgangssignale der einzelnen Filter, um eventuell vorhandene zeitliche Unsynchronitäten bei der Berechnung des Audiotestsignals bzw. des Audioreferenzsignals auszugleichen.

Der Vergleich des Audioreferenzsignals mit dem Audiotestsignal wird, wie es erwähnt wurde, gewissermaßen "hinter der Gehörschnecke" durchgeführt. Die Pegeldifferenzen zwischen einem Ausgangssignal eines Filters der Filterbank für das Audiotestsignal und dem Ausgangssignal des entsprechenden Filters der Filterbank für das Audioreferenzsignal wird erfaßt und in eine Detektionswahrscheinlichkeit abgebildet, die berücksichtigt, ob eine Pegeldifferenz ausreichend groß ist, um von dem Gehirn als solche erkannt zu werden. Die gehörangepaßte Qualitätsbeurteilung gemäß der vorliegenden Erfindung erlaubt eine gemeinschaftliche Auswertung von Pegeldifferenzen mehrerer aneinander angrenzender Filter, um ein Maß für eine subjektiv empfundene Störung in der Bandbreite, die durch die gemeinsam ausgewerteten Filter definiert ist, zu erreichen. Die Bandbreite wird, um einen dem Ohr angepaßten subjektiven Eindruck zu erhalten, kleiner oder gleich einer psychoakustischen Frequenzgruppe sein.

Bevorzugte Ausführungsbeispiele der vorliegenden Erfindung werden nachfolgend bezugnehmend auf die beiliegenden Zeichnungen detaillierter erläutert. Es zeigen:

- Fig. 1 eine Darstellung der Verdeckung von Tönen durch Schmalbandrauschsignale bei verschiedenen Frequenzen;
- Fig. 2 das Prinzip der Verdeckung im Zeitbereich;
- Fig. 3 ein allgemeines Blockdiagramm eines Audio-Meßsystems

Fig. 4 ein Blockdiagramm der Vorrichtung zur gehörangepaßten Qualitätsbeurteilung von Audiosignalen gemäß der vorliegenden Erfindung;

- Fig. 5 ein Blockdiagramm einer Filterbank aus Fig. 4;
- Fig. 6 eine beispielhafte Darstellung zur Verdeutlichung der Konstruktion eines Verdeckungsfilters;
- Fig. 7 eine Darstellung zur Verdeutlicheung der Konstruktion eines Verdeckungsfilters unter Berücksichtigung der Außen- und Mittelohr-Übertragungsfunktion und des internen Rauschens;
- Fig. 8 ein detailliertes Blockdiagramm der Vorrichtung zur gehörangepaßten Qualitätsbeurteilung von Audiosignalen gemäß der vorliegenden Erfindung;
- Fig. 9 eine Darstellung beispielhafter Filterkurven mit verschiedenen Abtastraten;
- Fig. 10 eine Darstellung der Schwellenfunktion zur Abbildung von Pegeldifferenzen in einem Spektralabschnitt auf die Detektionswahrscheinlichkeit;
- Fig. 11 eine graphische Darstellung der lokalen Detektionswahrscheinlichkeit eines beispielhaften Audiotestsignals; und
- Fig. 12 eine graphische Darstellung der Frequenzgruppen-Detektionswahrscheinlichkeit des beispielhaften Audiotestsignals, das in Fig. 11 verwendet wurde.
- Fig. 3 zeigt ein allgemeines Blockdiagramm eines Audio-Meßsystems, das in seinen Grundzügen der vorliegenden Erfindung entspricht. Einem Meßverfahren wird einerseits ein unverar-

beitetes Ausgangssignal einer Tonsignalquelle (Referenz) und andererseits ein aus einer Übertragungsstrecke, wie z.B. einer Audio-Codierer/Decodierer-Einrichtung (oder "Audio-Codec"), kommendes, zu bewertendes Signal (Test) zugeführt. Das Meßverfahren berechnet daraus verschiedene Kenngrößen, die die Qualität des Testsignals im Vergleich zum Referenzsignal beschreiben.

Eine Grundidee beim erfindungsgemäßen Verfahren zur Qualitätsbeurteilung von Audiosignalen besteht darin, daß eine genaue gehörangepaßte Analyse nur möglich ist, wenn gleichzeitig die zeitliche und die spektrale Auflösung möglichst hoch sind. Bei allen bekannten Meßverfahren ist entweder die zeitliche Auflösung durch die Verwendung einer diskreten Fourier-Transformation (DFT) sehr beschränkt (Blocklänge in der Regel 10,67 ms bis 21,33 ms) oder die spektrale Auflösung wurde durch eine zu kleine Anzahl von Analysekanälen zu stark verringert. Das erfindungsgemäße Verfahren zur Qualitätsbeurteilung von Audiosignalen liefert eine hohe Anzahl (241) von Analysekanälen bei einer hohen zeitlichen Auflösung von 0,67 ms.

Fig. 4 zeigt ein Blockdiagramm der Vorrichtung zur gehörangepaßten Qualitätsbeurteilung von Audiosignalen gemäß der vorliegenden Erfindung, die das Verfahren der vorliegenden Erfindung ausführt. Das Verfahren zur gehörangepaßten Qualitätsbeurteilung von Audiosignalen oder zur objektiven Audiosignalbewertung (OASE; OASE = Objectiv Audio Signal Evaluation) erzeugt zunächst eine interne Darstellung eines Audioreferenzsignals 12 bzw. eines Audiotestsignals 14. Zu diesem Zweck wird das Audioreferenzsignal 12 in eine erste Filterbank 16 eingespeist, welche das Audioreferenzsignal gemäß seiner spektralen Zusammensetzung in Audioreferenzteilsignale 18 zerlegt. Analog dazu wird das Audiotestsignal 14 in eine zweite Filterbank 20 eingespeist, welche wiederum aus dem Audiotestsignal 14 gemäß der spektralen Zusammensetzung desselben eine Mehrzahl von Audiotestteilsignalen 22 erzeugt. Eine erste Modellierungseinrichtung 24 bzw. eine

zweite Modellierungseinrichtung 26 zur Modellierung der zeitlichen Verdeckung modelliert den Einfluß der bereits beschriebenen Verdeckung im Zeitbereich bezüglich jedes Audioreferenzteilsignals 18 bzw. jedes Audiotestteilsignals 22.

An dieser Stelle sei angemerkt, daß die gehörangepaßte Qualitätsbeurteilung von Audiosignalen gemäß der vorliegenden Erfindung ebenfalls durch eine einzige Filterbank oder durch eine einzige Modellierungseinrichtung zur Modellierung der zeitlichen Verdeckung ausgeführt werden kann. Lediglich aus Darstellungsgründen sind für das Audioreferenzsignal 12 bzw. für das Audiotestsignal 14 jeweils eigene Einrichtungen gezeichnet. Wenn zur spektralen Zerlegung des Audioreferenzsignals und des Audiotestsignals eine einzige Filterbank verwendet wird, muß beispielsweise während der Verarbeitung des Audiotestsignals die bereits vorher ermittelte spektrale Zusammensetzung des Audioreferenzsignals zwischengespeichert werden können.

Die bezüglich der zeitlichen Verdeckung modellierten Audioreferenzteilsignale 18 bzw. Audiotestteilsignale 22 werden
einer Auswertungseinrichtung 28 zugeführt, welche eine nachfolgend beschriebene Detektion und Gewichtung der erhaltenen
Ergebnisse durchführt. Die Auswertungseinrichtung 28 gibt
eines oder eine Mehrzahl von Modellausgangswerten MAW1 ...
MAWn aus, die auf verschiedene Arten und Weisen Unterschiede
zwischen dem Audioreferenzsignal 12 und dem von dem Audioreferenzsignal 12 durch Codierung und Decodierung abgeleiteten
Audiotestsignal 14 darstellen. Wie es nachfolgend beschrieben wird, ermöglichen die Modellausgangswerte MAW1 ... MAWn
eine frequenz- und zeitselektive Qualitätsbeurteilung des
Audiotestsignals 14.

Die interne Darstellung des Audioreferenzsignals 12 bzw. des Audiotestsignals 14, die der Auswertung in der Auswertungseinrichtung 28 zugrunde liegen, entsprechen den Informationen, die vom Ohr über den Hörnerv dem menschlichen Gehirn

übermittelt werden. Durch die Ausgabe mehrerer Modellausgangswerte MAW1 ... MAWn ist eine detailliertere Aussage über den qualitativen und auch subjektiven Eindruck möglich, als wenn lediglich ein einzelner Modellausgangswert ausgegeben werden würde. Insbesondere subjektive Unterschiede in der Gewichtung verschiedener Artefakte können sich damit weniger störend auswirken.

Fig. 5 zeigt den Aufbau der ersten Filterbank 16 bzw. der zweiten Filterbank 20, falls zwei getrennte Filterbanken verwendet werden. Falls lediglich eine Filterbank für die Verarbeitung beider Signale in Kombination mit einer Zwischenspeicherung verwendet wird, stellt Fig. 5 den Aufbau der einzigen verwendeten Filterbank dar. In einen Signaleingang 40 wird ein in seine spektrale Zusammensetzung zu zerlegendes Audiosignal eingegeben, um eine Mehrzahl von Teilsignalen 18, 22 am Ausgang der Filterbank 16 bzw. 20 zu erhalten. Die Filterbank 16, 20 ist in eine Mehrzahl von Unterfilterbänken 42a bis 42f gegliedert. Das an dem Signaleingang 40 anliegende Signal läuft direkt in die erste Unterfilterbank 42a. Um in die zweite Unterfilterbank 42b zu gelangen, wird das Signal mittels eines ersten Tiefpaßfilters 44b gefiltert und mittels einer ersten Dezimiereinrichtung 46 bearbeitet, damit das Ausgangssignal der Dezimiereinrichtung 46b eine Datenrate von 24 kHz besitzt. Die Dezimiereinrichtung 46 entfernt also jeden zweiten Wert des an dem Signaleingang 40 anliegenden Datenstroms, um den Rechenaufwand und die zu verarbeitende Datenmenge der Filterbank wirksam zu halbieren. Das Ausgangssignal der ersten Dezimiereinrichtung 46b wird in die zweite Unterfilterbank eingespeist. Weiterhin wird dasselbe in ein zweites Tiefpaßfilter 44c und in eine darauffolgende zweite Dezimiereinrichtung 46c eingespeist, um die Datenrate desselben wieder zu halbieren. Die dann entstehende Datenrate beträgt 12 kHz. Das Ausgangssignal der zweiten Dezimiereinrichtung 46c wird wiederum in die dritte Unterfilterbank 42c eingespeist. Auf ähnliche Weise werden die Eingangssignale für die anderen Filterbanken 42d, 42e und 42f erzeugt, wie es in Fig. 5 dar-

gestellt ist. Die Filterbank 16, 20 implementiert somit eine sogenannte Multirate-Struktur, da sie eine Mehrzahl von Unterfilterbanken 42a - 42f aufweist, welche mit mehreren ("multi") jeweils unterschiedlichen Abtastraten ("rates") arbeiten.

Jede Unterfilterbank 42a - 42b setzt sich wiederum aus einer Mehrzahl von Bandpaßfiltern 48 zusammen. Bei einem bevorzugten Ausführungsbeispiel der vorliegenden Erfindung enthält die Filterbank 16, 20 241 einzelne Bandpaßfilter 48, die in einem gleichmäßigen Raster auf der Bark-Skala angeordnet sind, wobei sich ihre Mittenfrequenzen um 0,1 Bark unterscheiden. Die Einheit Bark ist für Fachleute auf dem Gebiet der Psychoakustik bekannt und beispielsweise in E. Zwicker, Psychoakustik, Springer-Verlag, Berlin Heidelberg New York, 1982, beschrieben.

Fig. 9 zeigt einige beispielhafte Filterkurven mit den Abtastraten 3 kHz, 12 kHz und 48 kHz. Die linke Gruppe von Filterkurven in Fig. 9 entspricht der Abtastrate von 3 kHz, während die mittlere Kurve einer Abtastrate von 12 kHz entspricht und die rechte Gruppe für Abtastrate von 48 kHz gilt.

Prinzipiell ergibt sich die minimale Abtastrate für jedes einzelne Bandpaßfilter 28 aus dem Punkt, an dem seine obere Flanke die Dämpfung -100 dB in Fig. 9 unterschreitet. Aus Gründen der Einfachheit wurde jedoch nur immer die nächsthöhere Abtastrate für jedes Bandpaßfilter 48 gewählt, welche der Formel  $f_A = 2^{-n} \cdot 48$  kHz erfüllt, wobei  $f_A$  die Datenoder Abtastrate des einzelnen betrachteten Bandpaßfilters 48 ist, und der Index n von 1 bis 5 läuft, wodurch sich die in Fig. 9 gezeigten Gruppierungen ergeben. Analog dazu ergibt sich die Gliederung der Filterbank 16, 20 in die fünf Unterfilterbanken FB1 bis FB5. Alle Filter, die auf der gleichen Abtastrate arbeiten, können eine gemeinsame Vorverarbeitung durch das jeweilige Tiefpaßfilter 44b bis 44f und die jeweilige Dezimiereinrichtung 46b bis 46f nutzen. Das Zustande-

kommen der einzelnen Filtererregungskurven bzw. Filterfunktionen wird nachfolgend detailliert dargestellt.

Alle in Fig. 5 gezeigten Bandpaßfilter 48 sind bei einem bevorzugten Ausführungsbeispiel mittels digitaler FIR-Filter realisiert, von denen jedes FIR-Filter 128 Filterkoeffizienten aufweist, die auf für Fachleute bekannte Art und Weise errechnet werden können, wenn die Filterkurve bzw. die Filterfunktion bekannt ist. Dies kann durch eine schnelle Faltung erreicht werden, wobei alle Filter von FBO (42a) und LP1 (44b) (LP = Low Pass = Tiefpaß) gemeinschaftlich eine FFT zur Berechnung der Filter benutzen können. Die Grenzfrequenzen der Tiefpaßfilter 44b bis 44f müssen gewählt werden, um zusammen mit der für die jeweilige Unterfilterbank maßgeblichen Abtastrate keine Verletzung des Abtasttheorems zu bewirken.

An dieser Stelle sei angemerkt, daß das Ausgangssignal 1, 2, ..., 241 jedes Filters, d.h. ein Testteilsignal bzw. Referenzteilsignal, eine Bandbreite aufweist, die durch das entsprechende Filter, das das Teilsignal erzeugt hat, definiert ist. Diese Bandbreite eines einzigen Filters wird auch als Spektralabschnitt bezeichnet. Die Mittenfrequenz eines Spektralabschnitts entspricht also der Mittenfrequenz des entsprechenden Bandfilters, während die Bandbreite eines Spektralabschnitts gleich der Bandbreite des entsprechenden Filters ist. Somit ist es offensichtlich, daß sich die einzelnen Spektralabschnitte bzw. Bandfilterbandbreiten überlappen, da die Spektralabschnitte breiter als 0,05 Bark sind. (0,1 Bark ist der Abstand der Mittenfrequenz eines Bandfilters zum nächsten Bandfilter.)

Fig. 6 stellt die Konstruktion eines Verdeckungsfilters 48 beispielhaft an dem Bandpaßfilter mit der Mittenfrequenz  $f_m$  von 1.000 Hz dar. An der Ordinate von Fig. 6 ist die Filterdämpfung in dB aufgetragen, während die Abszisse die linksbzw. rechtsseitige Frequenzabweichung von der Mittenfrequenz  $f_m$  in Bark aufträgt. Der Parameter in Fig. 6 ist der Schall-

druckpegel eines durch das Filter gefilterten Audiosignals. Der Schalldruckpegel des gefilterten Audiosignals kann sich von 0 dB bis zu 100 dB erstrecken. Wie es bereits erwähnt wurde, hängt die Filterform eines modellmäßig gesehenen Bandfilters des menschlichen Ohrs von dem Schalldruckpegel des empfangenen Audiosignals ab. Wie es in Fig. 6 zu sehen ist, ist die linke Filterflanke bei hohen Schalldruckpegeln relativ flach und wird zu kleineren Schalldruckpegeln hin steiler. Dagegen geht die steilere Flanke bei kleineren Schalldruckpegeln schneller in die Ruhehörschwelle über, die in Fig. 6 die geraden Fortsetzungen der einzelnen beispielhaften Filterflanken sind.

Die Abhängigkeit vom Schalldruckpegel des Audiosignals könnte durch eine Umschaltung zwischen verschiedenen Koeffizientensätzen der digitalen Bandfilter 48 der Filterbank erreicht werden. Dies hätte neben einer sehr hohen Komplexität aber auch den Nachteil, daß das Verfahren sehr anfällig gegen Veränderungen der Abhörlautstärke werden würde. (Siehe Kh. Brandenburg und Th. Sporer. "NMR" und "Masking Flag": Evaluation of quality using perceptual criteria. In Proceedings of the 11th International Conference of the AES, Portland, 1992).

Bei der gehörangepaßten Qualitätsbeurteilung von Audiosignalen gemäß der vorliegenden Erfindung wurde deshalb ein anderer Weg gewählt. Aus den Filterkurven, die sich für unterschiedliche Schalldruckpegel ergeben würden, wird eine Kurve 50 für den schlechtesten Verdeckungsfall oder "Worst-Case" gebildet. Die Worst-Case-Kurve 50 ergibt sich bei einer bestimmten Frequenzabweichung von der Mittenfrequenz  $f_m$  aus dem Minimalwert aller Schalldruckpegelkurven in einem bestimmten Nennschalldruckpegelbereich, der sich beispielsweise von 0 dB bis 100 dB erstrecken kann. Die Worst-Case-Kurve erhält so nahe der Mittenfrequenz eine steile Flanke und wird mit wachsendem Abstand zur Mittenfrequenz flacher, wie es durch die Kurve 50 in Fig. 6 angedeutet ist. Wie es ebenfalls aus Fig. 6 zu sehen ist, ist die bezüglich der

Mittenfrequenz f<sub>m</sub> rechte Filterflanke eines Bandpaßfilters 48 abgesehen von der Ruhehörschwelle nur gering von dem Schalldruckpegel des gefilterten Audiosignals abhängig. D.h., daß die Neigungen der rechten Kurvenflanken für einen Schalldruckpegel von 0 dB bis zu einem Schalldruckpegel von 100 dB nahezu gleich sind.

Bei der gehörangepaßten Qualitätsbeurteilung von Audiosignalen gemäß der vorliegenden Erfindung wird ferner der Einfluß der Außen- und Mittelohrübertragungsfunktion und des internen Rauschens, das beispielsweise durch den Blutstrom im Ohr verursacht wird, berücksichtigt. Die sich daraus ergebenden Kurven für einzelne Schalldruckpegel von 0 dB bis 100 dB sind in Fig. 7 dargestellt. Im Gegensatz zu Fig. 6 ist bei Fig. 7 an der Abszisse der Spektralbereich in Hz aufgetragen und nicht die Frequenzskala in Bark, welche auch Tonheitsskala bezeichnet wird. Mathematisch formuliert kann die Außen- und Mittelohr-Übertragungsfunktion und das interne Rauschen des Ohrs durch folgende Gleichung modelliert werden:

$$\frac{a_0(f)}{dB} = -6.5 \cdot e^{-0.6(\frac{f}{1000Hz} - 3.3)^2} + 1.82(\frac{f}{1000Hz})^{-0.8} + 0.5 \cdot 10^{-3}(\frac{f}{1000Hz})^4$$

Die Größe  $a_0(f)$  stellt die Dämpfung des Ohrs über dem gesamten Frequenzbereich dar und ist in dB angegeben.

Die Verdeckungskurven oder Filterkurven für die einzelnen Bandpaßfilter 48 können durch folgende mathematische Gleichung abhängig von der Mittenfrequenz  $f_m$  und abhängig von dem Schalldruckpegel L modelliert werden:

$$\frac{A(\Delta b, f_m, L)}{dB} = A_0(f_m, L) + \frac{S_1 - S_2(f_m, L)}{2} \cdot \left(\frac{\Delta b}{Bark} + C_1(f_m, L)\right) - \frac{S_1 + S_2(f_m, L)}{2} \sqrt{C_2 + \left(\frac{\Delta b}{Bark} + C_1(f_m, L)\right)^2}$$

Die einzelnen in der Gleichung verwendeten Größen sind im nachfolgenden aufgestellt:

fm = Mittenfrequenz eines Bandpaßfilters;

Δb = Frequenzunterschied in Bark zwischen der Mittenfrequenz f<sub>m</sub> des Filters und einer Testfrequenz;

f<sub>m</sub> = Mittenfrequenz eines Bandpaßfilters;

L = Schalldruckpegel des gefilterten Audiosignals;

Abrundungsfaktor  $C_2 = 0,1;$ 

Steilheit der unteren Flanke  $S_1 = 27$  (dB/Bark);

Steilheit der oberen Flanke:

$$S_2(f_m,L) = 24 + 230Hz/f_m - 0,2 \cdot L/dB;$$

Konstante C<sub>1</sub>:

$$c_1(f_m,L) = (s_1 - s_2(f_m,L)/2 \cdot \sqrt{c_2/(s_1 \cdot s_2(f_m,L))};$$

Konstante 
$$A_0(f_m,L) = \sqrt{C_2 \cdot S_1 \cdot S_2(f_m,L)};$$

Die Umrechungsgleichung von der Frequenzskala in Hertz zur Frequenzsskala in Bark lautet folgendermaßen:

$$\frac{Hz2Bark(f)}{Bark} = 13 \cdot \arctan(0.76 \frac{f}{1000Hz}) + 3.5 \cdot \arctan((\frac{f}{7500Hz})^2)$$

Wird in die Verdeckungskurve A eine virtuelle Ruhehörschwelle bei -10 dB miteinbezogen, so ergibt sich eine Grenzverdeckungskurve  $A_{\text{lim}}$ , welche folgendermaßen gegeben ist:

$$A_{lim}(\Delta b, f_m, L) = \max(A(\Delta b, f_m, L), -L - 10dB)$$

Der Übergang von der Bark-Skala auf die Hertz-Skala für die Verdeckungskurve inklusive der virtuellen Ruhehörschwelle zusammen mit der Einbeziehung der Außen- und Mittelohr-Übertragungsfunktion  $A_0(f)$  liefert die erweiterte Grenzverdeckungskurve  $A_{lim}$ , die noch von dem Schalldruckpegel des Audiosignals abhängt:

$$\hat{A}_{lim}(f, f_m, L) = A_{lim}(Hz2Bark(f_m) - Hz2Bark(f), f_m, L) - a_0(f)$$

Wie es bereits erwähnt wurde, ist es zu aufwendig, für jeden Schalldruckpegel eine eigene Filterkurve bzw. Verdeckungskurve zu wählen, weshalb eine Worst-Case-Kurve errechnet wird. Die Worst-Case-Kurve  $A_{WC}(f, f_m)$  gibt die letztendlich verwendete Dämpfung eines Filters mit der Mittenfrequenz  $f_m$  bei der aktuellen Frequenz f in Hz an. Die mathematische Formulierung der Worst-Case-Kurve  $A_{WC}$  lautet folgendermaßen:

$$A_{wc}(f, f_m) = \min(\hat{A}_{lim}(f, f_m, L); -3 \text{ dB} \le L \le 120 \text{ dB})$$

Fig. 8 zeigt ein Blockdiagramm der Vorrichtung bzw. des Verfahrens zur gehörangepaßten Qualitätsbeurteilung von Audiosignalen gemäß der vorliegenden Erfindung. Wie es bereits im Zusammenhang mit Fig. 5 beschrieben worden ist, wird in die Filterbank 16 das Audioreferenzsignal 12 eingespeist, um Audioreferenzteilsignale 18 zu erzeugen. Analog dazu wird das Audiotestsignal 14 in die Filterbank 20 eingespeist, um Audiotestteilsignale 22 zu erzeugen. An dieser Stelle sei angemerkt, daß es aus Fig. 6 und Fig. 7 ersichtlich ist, daß sich die einzelnen Filterkurven der Bandpaßfilter 48 jeweils überlappen, da die Mittenfrequenzen der einzelnen Filter jeweils lediglich um 0,1 Bark beabstandet sind. Jedes Bandpaßfilter 48 soll somit die Erregung einer Haarzelle auf der Basilarmembran des menschlichen Ohrs modellieren.

Die Ausgangssignale der einzelnen Bandpaßfilter der Filterbank 16 bzw. der Filterbank 20, welche einerseits die Audioreferenzteilsignale 18 bzw. die Audiotestteilsignale 22 sind, werden in jeweilige Modellierungseinrichtungen 24 bzw. 26 eingespeist, welche die zeitliche Verdeckung, die Eingangs beschrieben worden ist, modellieren sollen. Die Modellierungseinrichtungen 24, 26 dienen der Modellierung der Ruhehörschwelle und der Nachverdeckung. Die Ausgangswerte der Filterbank werden quadriert und zu denselben wird ein konstanter Wert für die Ruhehörschwelle addiert, da die Frequenzabhängigkeit der Ruhehörschwelle bereits in der Filterbank berücksichtigt worden ist, wie es vorher erläutert wur-

de. Ein rekursives Filter mit einer Zeitkonstante von 3 ms glättet das Ausgangssignal. Daraufhin folgt ein nichtlineares Filter, welches einerseits als Integrator die über die Dauer eines Schallereignisses auflaufende Energie aufintegriert, und welches andererseits den exponentiellen Abfall der Erregung nach dem Ende eines Schallereignisses modelliert. Einzelheiten des Aufbaus der Modellierungseinrichtungen 24 und 26 sind in M. Karjalainen, A new auditory model for the evaluation of sound quality of audio system, Proceedings of the ICASSP, Seiten 608 - 611, Tampa, Florida, März 1985, IEEE, beschrieben. Es sei angemerkt, daß diese Modellierung der zeitlichen Verdeckung die Bandbreite in allen Filterbändern für alle Bandpaßfilter 48 so weit reduziert, daß ein weiterer Unterabtastschritt möglich ist. durch den alle Bänder auf die gleiche Abtastrate von 1,5 kHz gebracht werden können.

Die Ausgangssignale der Modellierungseinrichtungen 24, 26 werden anschließend in Detektionsberechnungseinrichtungen 52 eingespeist, deren Funktion im nachfolgenden erläutert wird. Wie es in Fig. 8 gezeigt ist, werden in die Detektionsberechnungseinrichtung 52 für das erste Bandpaßfilter mit der Nr. 1 das Audioreferenzteilsignal, das aus dem Bandpaßfilter mit der Nr. 1 ausgegeben wird, und das Audiotestteilsignal, das aus dem Bandpaßfilter Nr. 1 der Filterbank für das Audiotestsignal ausgegeben wird, eingespeist. Die Detektionsberechnungseinrichtung 52 bildet zum einen eine Differenz zwischen diesen beiden Pegeln und bildet zum anderen den Pegelunterschied zwischen dem Audioreferenzteilsignal und dem Audiotestteilsignal in eine Detektionswahrscheinlichkeit ab. Die Erregungen in Filterbändern 48 mit gleicher Mittenfrequenz  $f_m$  vom Audioreferenzsignal und vom Audiotestsignal werden also subtrahiert und mit einer Schwellenfunktion verglichen, die in Fig. 10 dargestellt ist. Diese in Fig. 10 dargestellte Schwellenfunktion bildet den Absolutbetrag der Differenz in dB auf eine sog. "lokale Detektionswahrscheinlichkeit" ab. Die eigentliche Detektionsschwelle für das menschliche Gehirn beträgt 2,3 dB. Es ist jedoch wichtig,

anzumerken, daß um die eigentliche Detektionsschwelle von 2,3 dB eine gewisse Unsicherheit der Detektion auftritt, weswegen die in Fig. 10 gezeigte Wahrscheinlichkeitskurve verwendet wird. Eine Pegeldifferenz von 2,3 dB wird auf eine Detektionswahrscheinlichkeit von 0,5 abgebildet. Die einzelnen Detektionsberechnungseinrichtungen 52, die jeweils Bandpaßfiltern 48 zugeordnet sind, arbeiten alle parallel zueinander, wobei sie ferner auf zeitlich serielle Art und Weise jede Pegeldifferenz in eine Detektionswahrscheinlichkeit pi,t abbilden.

An dieser Stelle sei angemerkt, daß die gehörangepaßte Qualitätsbeurteilung von Audiosignalen im Zeitbereich arbeitet, wobei mittels digitaler Filter in der Filterbank die zeitdiskreten Eingangssignale des Audioreferenzsignals 12 und des Audiotestsignals 14 sequentiell verarbeitet werden. Somit ist es offensichtlich, daß die Eingangssignale für die Detektionsberechnungseinrichtungen 52 ebenfalls ein serielzeitlicher Datenstrom sind. Die Ausgangssignale der Detektionsberechnungseinrichtungen 52 sind somit ebenfalls zeitlich serielle Datenströme, die für jeden Frequenzbereich des entsprechenden Bandpaßfilters 48 zu jedem Zeitpunkt bzw. Zeitschlitz die Detektionswahrscheinlichkeit darstellen. Eine niedrige Detektionswahrscheinlichkeit einer speziellen Detektionsberechnungseinrichtung 52 in einem bestimmten Zeitschlitz läßt die Beurteilung zu, daß das von dem Audioreferenzsignal 12 durch Codierung und Decodierung abgeleitete Audiotestsignal 14 in dem speziellen Frequenzbereich und zu dem speziellen Zeitpunkt einen Codierungsfehler aufweist, der wahrscheinlich vom Gehirn nicht erfaßt werden wird. Eine große Detektionswahrscheinlichkeit sagt hingegen aus, daß das menschliche Gehirn wahrscheinlich einen Codierungs- bzw. Decodierungsfehler des Audiotestsignals erfassen wird, da das Audiotestsignal in dem speziellen Zeitschlitz und in dem speziellen Frequenzbereich einen hörbaren Fehler aufweist.

Die Ausgangssignale der Detektionsberechnungseinrichtungen

52 können wahlweise in eine Globaldetektionseinrichtung 54 oder in eine Mehrzahl von Gruppendetektionseinrichtungen 56 eingespeist werden. Die Globaldetektionseinrichtung 54 hingegen gibt eine globale Detektionswahrscheinlichkeit aus, welche für ein bestimmtes international verwendetes Testsignal in Fig. 11 gezeigt ist. Im oberen Diagramm von Fig. 11 ist als Ordinate die Frequenz in Bark eingetragen, während die Abszisse die Zeit in ms wiedergibt. In dem unteren Diagramm ist einer speziellen Schattierung des oberen Diagramms eine bestimmte Detektionswahrscheinlichkeit in Prozent zugeordnet. Weiße Flächen im oberen Diagramm stellen yom Gehirn hundertprozentig erfaßbare Codierungs- bzw. Decodierungsfehler dar. Das verwendete Referenzsignal ist in der Technik bekannt und findet sich auf der CD SQAM (SQAM = Sound Quality Assessment Material = Tonqualitätsbeurteilungsmaterial) auf der Spur 10 und wird SQAM, Track 10, bezeichnet. Hieraus word ein absichtlich fehlerhaft codiertes bzw. decodiertes Tonsignal gewonnen, das sich ergibt, wenn ein zweigestrichenes a auf einem Violoncello gespielt wird und absichtlich fehlerhaft codiert und decodiert wird. Die Länge desselben beträgt 2,7 Sekunden, wobei jedoch in Fig. 11 und ebenso auch in Fig. 12 lediglich die ersten 1,2 Sekunden des Beispielsignals graphisch dargestellt sind.

Die Gruppendetektionseinrichtungen 56 arbeiten folgendermaßen. Zuerst bilden sie aus den in dieselben eingespeisten Detektionswahrscheinlichkeiten p<sub>i,t</sub> die Gegenwahrscheinlichkeiten p<sub>j,t</sub> eines Zeitschlitzes t. Die Gegenwahrscheinlichkeit pg ist ein Maß dafür, daß in einem Zeitschlitz t keine Störung erfaßt werden kann. Werden nun die Gegenwahrscheinlichkeiten der Pegeldifferenzen von mehreren Bandpaßfiltern multipliziert, wie es durch das Produktsymbol in Fig. 8 dargestellt ist, so ergibt sich aus der Gegenwahrscheinlichkeit der durch die Produktbildung entstandenen Gegenwahrscheinlichkeit wiederum die globale Detektionswahrscheinlichkeit des Zeitschlitzes, wenn die Ausgangssignale der Detektionsberechnungseinrichtungen 52 alle in die Globaldetektionseinrichtung 54 eingespeist werden, wie es in

Fig. 8 gezeigt ist. Wird diese Detektionswahrscheinlichkeit über der Zeit gemittelt, so erhält man die mittlere globale Detektionswahrscheinlichkeit. Eine genauere Aussage über die Qualität des Audiotestsignals bietet allerdings ein Histogramm, welches angibt, in wieviel Prozent der Zeitschlitze die globale Detektionswahrscheinlichkeit größer als 10%, 20%, ..., 90% ist.

Fig. 11 zeigt, wie es bereits erwähnt wurde, die lokale Detektionswahrscheinlichkeit, wenn direkt die Ausgangssignale der Detektionsberechnungseinrichtungen graphisch dargestellt werden. Es ist deutlich zu sehen, daß im unteren Frequenzbereich etwa unterhalb 5 Bark (ca 530 Hz) und oberhalb von 2 Bark (200 Hz) im Zeitbereich von etwa 100 ms bis 1.100 ms Codierungs- bzw. Decodierungsfehler des Audiotestsignals vom Gehirn mit sehr hoher Wahrscheinlichkeit detektiert werden. Zusätzlich ist eine kurze Störung bei 22 Bark zu sehen.

Die Störungen werden in der graphischen Darstellung deutlicher, wenn statt der lokalen Detektionswahrscheinlichkeit, welche die Ausgaben der Detektionsberechnungseinrichtungen einrichtung 52 sind, eine Frequenzgruppendetektionswahrscheinlichkeit gewählt wird, welche durch die Gruppendetektionseinrichtungen 56 berechnet wird. Die Gruppendetektionswahrscheinlichkeit stellt ein Maß dafür dar, daß in dem eine Frequenzgruppe umfassenden Bereich um ein Filter k eine Störung wahrnehmbar ist.

Bei einem bevorzugten Ausführungsbeispiel der vorliegenden Erfindung werden jeweils zehn benachbarte lokale Detektionswahrscheinlichkeiten zusammengefaßt. Da zehn benachbarte Bandfilter jeweils um 0,1 Bark voneinander beabstandet sind, entspricht die Zusammengruppierung von zehn benachbarten Detektionswahrscheinlichkeiten einem Frequenzbereich von 1 Bark. Es ist sinnvoll, die Zusammengruppierung benachbarter Detektionswahrscheinlichkeiten derart zu wählen, daß sich Frequenzbereiche ergeben, die mit den psychoakustischen Frequenzgruppen im wesentlichen übereinstimmen. Dadurch kann

die Frequenzgruppenbildung des vorteilhafte Weise auf menschlichen Ohres simuliert werden, um einen eher subjektiven Höreindruck von Störungen ebenfalls graphisch anzeigen zu können. Beim Vergleich von Fig. 12 mit Fig. 11 stellt sich heraus, daß eine gruppenweise Zusammenfassung der Detektionswahrscheinlichkeiten offenbart, daß auch bei höheren Frequenzen als in Fig. 11 wahrscheinlich Codierungs- bzw. Decodierungsfehler des Audiotestsignals gehört werden können. Die Gruppendetektion, welche in Fig. 12 gezeigt ist, liefert also eine realistischere Qualitätsbeurteilung von Audiosignalen als die lokale Detektion in Fig. 11, da hier die Frequenzgruppenbildung im menschlichen Ohr simuliert wird. Die Unterschiede nebeneinander liegender Filterausgangswerte (wobei die Unterschiede kleiner oder gleich einer Frequenzgruppe gewählt werden), werden also zusammen ausgewertet und ergeben ein Maß für die subjektive Störung in dem entsprechenden Frequenzbereich.

Alternativ kann die Frequenzachse in drei Abschnitte (unter 200 Hz, 200 Hz bis 6.500 Hz, über 6.500 Hz) unterteilt werden. Die Pegel des Audioreferenzsignals bzw. des Audiotestsignals können ebenfalls in drei Abschnitte unterteilt werden (Stille; leise: bis 20 dB; laut: über 20 dB). Somit ergeben sich neun verschiedene Typen, denen ein Filterabtastwert angehören kann. Zeitabschnitte, in denen alle Filterausgangswerte beider Eingangssignale dem Typ Stille angehören, müssen nicht weiter betrachtet werden. Aus den übrigen sechs werden Maße für die Detektionswahrscheinlichkeit des Unterschieds zwischen den Eingangssignalen für jeden Zeitschlitz bestimmt, wie es oben erwähnt wurde. Zusätzlich zu der Bestimmung der Detektionswahrscheinlichkeit kann auch eine sog. Störlautheit definiert werden, die ebenfalls mit der Pegeldifferenz, die durch die Detektionsberechnungseinrichtungen 52 berechnet wird, korreliert ist, und angibt, wie stark ein Fehler stören wird. Anschließend werden getrennte Mittelwerte der Störlautheit und der Detektionswahrscheinlichkeit für jeden der sechs Typen berechnet.

Ferner werden Kurzzeitmittelwerte über einen Zeitraum von 10 ms berechnet, wobei die 30 schlechtesten Kurzzeitmittelwerte eines kompletten Audiosignals gespeichert werden. Die Mittelwerte wiederum über diese 30 Worst-Case-Werte und der Gesamtmittelwerte ergeben zusammen den Höreindruck. Hierbei ist anzumerken, daß Worst-Case-Werte sinnvoll sind, wenn Störungen sehr ungleichmäßig verteilt sind. Gesamtmittelwerte sind dagegen sinnvoll, wenn häufig kleine, jedoch hörbare Störungen auftreten. Die Entscheidung, ob die Gesamtmittelwerte oder die Worst-Case-Werte zur Beurteilung des Audiotestsignals herangezogen werden sollen, kann über eine Extremwert-Verknüpfung dieser beiden Beurteilungswerte erreicht werden.

Die bisher beschriebene gehörangepaßte Qualitätsbeurteilung von Audiosignalen bezog sich auf monoaurale bzw. Mono-Audiosignale. Die gehörangepaßte Qualitätsbeurteilung von Audiosignalen gemäß der vorliegenden Erfindung ermöglicht jedoch auch eine Beurteilung von binauralen oder stereophonen Audiotestsignalen durch eine nichtlineare Vorverarbeitung zwischen der Filterbank 16 bzw. 20 und der Detektion in den Detektionsberechnungseinrichtungen 52. Wie es für Fachleute bekannt ist, weisen stereophone Audiosignale jeweils einen linken und einen rechten Kanal auf. Der linke und rechte Kanal des Audiotestsignals bzw. des Audioreferenzsignals werden jeweils getrennt mittels eines nichtlinearen Eledas Transienten frequenzselektiv hervorhebt und stationäre Signale verringert, gefiltert. Die Ausgangssignale dieser Operation werden im nachfolgenden als das modifizierte Audiotestsignal bzw. das modifizierte Audioreferenzsignal bezeichnet. Die Detektion in den Detektionsberechnungseinrichtungen 52 wird nun nicht mehr einmal, wie es vorher beschrieben worden ist, sondern viermal durchgeführt, wobei jeweils folgende Eingangssignale abwechselnd in die Detektionsberechnungseinrichtungen 52 eingespeist werden:

erste Detektion, linker Kanal (D1L): linker Kanal des Audio-

referenzsignals mit linkem Kanal des Audiotestsignals;

erste Detektion, rechter Kanal (D1R): rechter Kanal des Audioreferenzsignals mit rechtem Kanal des Audiotestsignals;

zweite Detektion, linker Kanal (D2L): linker Kanal des modifizierten Audioreferenzsignals mit linkem Kanal des modifizierten Audiotestsignals; und

zweite Detektion, rechter Kanal (D2R): rechter Kanal des modifizierten Audioreferenzsignals mit rechtem Kanal des modifizierten Audiotestsignals.

Von den Detektionen D1L und D1R bzw. D2L und D2R wird nun jeweils der Worst-Case-Wert bestimmt, wonach die derart entstandenen Werte über einen gewichteten Mittelwert vereinigt werden, um die Qualität des stereophonen Audiotestsignals zu beurteilen.

### Patentansprüche

 Verfahren zur Qualitätsbeurteilung eines Audiotestsignals (14), das durch Codierung und Decodierung von einem Audioreferenzsignal (12) abgeleitet ist, mit folgenden Schritten:

Zerlegen des Audiotestsignals (14) gemäß seiner spektralen Zusammensetzung mittels einer ersten Filterbank (20) aus einander sich frequenzmäßig überlappenden, Spektralabschnitte definierenden Filtern (48) mit voneinander abweichenden Filterfunktionen, die jeweils aufgrund der Erregungskurven des menschlichen Ohrs bei der jeweiligen Filtermittenfrequenz ( $f_m$ ) festgelegt sind, in Audiotestteilsignale (22);

Zerlegen des Audioreferenzsignals (12) gemäß seiner spektralen Zusammensetzung mittels einer mit der ersten Filterbank (20) übereinstimmenden zweiten Filterbank (16) in Audioreferenzteilsignale (18);

spektralabschnittsweises Bilden der Pegeldifferenz zwischen den zu gleichen Spektralabschnitten gehörigen Audiotestteilsignalen (22) und Audioreferenzteilsignalen (18); und

spektralabschnittsweises Bestimmen einer Detektionswahrscheinlichkeit für die Erfassung eines Codierungsfehlers des Audiotestsignals (14) in dem betreffenden Spektralabschnitt aufgrund der jeweiligen Pegeldifferenz.

Verfahren nach Anspruch 1,

bei dem die Erregungskurve eine Außen- und Mittelohr-Übertragungsfunktion und internes Rauschen des menschlichen Ohrs berücksichtigt.

29

3. Verfahren nach Anspruch 1 oder 2,

bei dem die Erregungskurven der Filter (48) der ersten und der zweiten Filterbank (16, 20) gemäß der Mittenfrequenz der Filter festgelegt sind, um die zu hohen Frequenzen hin abnehmende Frequenzauflösung des menschlichen Ohrs anzunähern.

4. Verfahren nach einem der Ansprüche 1 bis 3,

bei dem die Erregungskurven der Filter (48) der ersten und der zweiten Filterbank (16, 20) gemäß dem Schalldruckpegel des Audiotestsignals bzw. des Audioreferenzsignals (12) festgelegt sind, um bei höheren Schalldruckpegeln flachere Filterflanken und niedrigere Ruhehörschwellen als bei niedrigen Schalldruckpegeln aufzuweisen.

5. Verfahren nach einem der Ansprüche 1 bis 3,

bei dem die Erregungskurven der Filter (48) der ersten und der zweiten Filterbank (16, 20) gemäß dem Schalldruckpegel des Audiotestsignals (14) bzw. des Audioreferenzsignals (12) festgelegt sind, damit jeweils eine Filterfunktion aus Minimaldämpfungswerten aller in einem Schalldruckpegelbereich möglichen, einem bestimmten Schalldruckpegel entsprechenden Filterfunktionen gebildet wird.

6. Verfahren nach einem der Ansprüche 1 bis 5,

das vor dem Schritt des spektralabschnittsweisen Bildens der Pegeldifferenz die Schritte des spektralabschnittsweisen Modellierens der zeitlichen Verdeckung des Audiotestsignals (14) und des Audioreferenzsignals (12) aufweist.

7. Verfahren nach Anspruch 6,

bei dem der Schritt des spektralabschnittsweisen Modellierens der zeitlichen Verdeckung das spektralabschnittsweise Integrieren eines Audioreferenzsignals
(12) oder eines Audiotestsignals (14) zur Berücksichtigung der Vorverdeckung und das spektralabschnittsweise
exponentielle Dämpfen des Audioreferenzsignals (12)
oder des Audiotestsignals (14) zur Berücksichtigung der
Nachverdeckung aufweist.

8. Verfahren nach einem der Ansprüche 1 bis 7,

bei dem die Filter (48) der ersten und der zweiten Filterbank (16, 20) unterschiedliche Abtastraten aufweisen, wobei die Abtastrate durch den Schnittpunkt der frequenzmäßig oberhalb der Mittenfrequenz ( $f_m$ ) eines Filters (48) angeordneten Filterflanke mit einer vorbestimmten Filterdämpfung bestimmt ist.

9. Verfahren nach Anspruch 8,

bei dem das Audiotestsignal (14) und das Audioreferenzsignal (12) mit einer Abtastrate diskretisiert sind, wobei die unterschiedlichen Abtastraten durch den Quotienten der ursprünglichen Abtastrate und einer Potenz von 2 bestimmt sind, wodurch mehrere benachbarte Filter (48) zu Unterfilterbanken (42a - 42f) gruppiert werden.

10. Verfahren nach einem der Ansprüche 1 bis 9,

bei dem vor dem Schritt des spektralabschnittsweisen Bildens der Pegeldifferenz eine Verzögerung zwischen dem Audioreferenzsignal (12) und dem Audiotestsignal (14) bestimmt und ausgeglichen wird.

11. Verfahren nach einem der Ansprüche 1 bis 10,

bei dem die Detektionswahrscheinlichkeit bei einer

Schwellenpegeldifferenz 0,5 beträgt und bei einer kleineren Pegeldifferenz als der Schwellenpegeldifferenz abnimmt und bei einer größeren Pegeldifferenz zunimmt.

12. Verfahren nach einem der Ansprüche 1 bis 11,

bei dem die Detektionswahrscheinlichkeiten nebeneinanderliegender Spektralabschnitte in einem Spektralbereich, der kleiner oder gleich einer psychoakustischen Frequenzgruppe ist, zusammen ausgewertet werden, wodurch eine subjektive Empfindung des Codierungsfehlers des Audiotestsignals (14) erreicht wird.

13. Verfahren nach einem der Ansprüche 1 bis 12,

bei dem mehrere zeitlich aufeinanderfolgende Detektionswahrscheinlichkeiten zu einem Zeitschlitz zusammengefaßt werden, und die mehreren zeitlich aufeinanderfolgenden Detektionswahrscheinlichkeiten verknüpft werden, um eine Gesamtdetektionswahrscheinlichkeit für einen Zeitschlitz zu erhalten.

14. Verfahren nach einem der Ansprüche 1 bis 13,

bei dem Kurzzeitmittelwerte der Detektionswahrscheinlichkeiten in einem Spektralabschnitt gebildet werden, und eine Anzahl von Kurzzeitmittelwerten eines Audiotestsignals gespeichert wird, wobei ein Gesamtmittelwert aller Kurzzeitmittelwerte zusammen mit den gespeicherten Kurzzeitmittelwerten einen Gesamthöreindruck des betreffenden Spektralabschnitts des Audiotestsignals (14) ergeben.

15. Verfahren nach einem der Ansprüche 1 bis 14,

bei dem das Audiotestsignal und das Audioreferenzsignal Stereosignale mit einem linken und einem rechten Kanal sind;

bei dem die Schritte des Zerlegens des Audiotestsignals und des Audioreferenzsignals das getrennte Zerlegen des linken und rechten Kanals der Signale mittels eines nichtlinearen Elements aufweisen, das Transienten hervorhebt und stationäre Signale verringert, um ein modifiziertes Audiotestsignal mit einem linken und einem rechten Kanal und ein modifiziertes Audioreferenzsignal mit einem linken und einem rechten Kanal zu erzeugen; und

bei dem das spektralabschnittsweise Bilden der Pegeldifferenz das Bilden der Pegeldifferenz zwischen den zu gleichen Spektralabschnitten gehörigen

Audiotestteilsignalen des linken Kanals und Audioreferenzteilsignalen des linken Kanals,

Audiotestteilsignalen des rechten Kanals und Audioreferenzteilsignalen des rechten Kanals,

modifizierten Audiotestteilsignalen des linken Kanals und modifizierten Audioreferenzteilsignalen des linken Kanals, und

modifizierten Audiotestteilsignalen des rechten Kanals und modifizierten Audioreferenzteilsignalen des rechten Kanals aufweist.

# 16. Verfahren nach Anspruch 15,

bei dem aus den Pegeldifferenzen der Signale für den linken und für den rechten Kanal spektralabschnittsweise der schlechteste Wert bestimmt wird;

bei dem aus den Pegeldifferenzen der modifizierten Signale für den linken und für den rechten Kanal spektralabschnittsweise der schlechteste Wert bestimmt

wird; und

bei dem der schlechteste Wert für das Audiotestsignal und der schlechteste Wert für das modifizierte Audiotestsignal über einen gewichteten Mittelwert vereinigt werden, um den Codierungsfehler des stereophonen Audiotestsignals zu erfassen.

17. Verfahren nach einem der Ansprüche 1 bis 16,

bei dem die erste und die zweite Filterbank (16, 20) eine einzige Filterbank sind, wobei während des Zerlegens des Audiotestsignals (14) oder des Audioreferenzsignals (12) die Audioreferenzteilsignale bzw. die Audiotestteilsignale zwischengespeichert werden.

18. Vorrichtung zur Qualitätsbeurteilung eines Audiotestsignals (14), das durch Codierung und Decodierung von einem Audioreferenzsignal (12) abgeleitet ist, mit folgenden Merkmalen:

einer ersten Filterbank (16) zum Zerlegen des Audiotestsignals (14) gemäß seiner spektralen Zusammensetzung in Audiotestteilsignale (22), wobei die erste Filterbank (16) sich einander frequenzmäßig überlappende, Spektralabschnitte definierende Filter mit voneinander abweichenden Filterfunktionen aufweist, die jeweils aufgrund der Erregungskurven des menschlichen Ohrs bei der jeweiligen Filtermittenfrequenz festgelegt sind;

einer zweiten Filterbank (20), die mit der ersten Filterbank (16) übereinstimmt, zum Zerlegen des Audioreferenzsignals (12) gemäß seiner spektralen Zusammensetzung in Audioreferenzteilsignale (18);

einer Berechnungseinrichtung zum spektralabschnittsweisen Bilden der Pegeldifferenz zwischen den zu gleichen Spektralabschnitten gehörigen Audiotestteilsignalen

34

WO 98/23130 PCT/EP97/05446

(22) und Audioreferenzteilsignalen (18); und

einer Zuweisungseinrichtung (52) zum spektralabschnittsweisen Bestimmen einer Detektionswahrscheinlichkeit für die Erfassung eines Codierungsfehlers des Audiotestsignals (14) in dem betreffenden Spektralabschnitt aufgrund der jeweiligen Pegeldifferenz.

### 19. Vorrichtung gemäß Anspruch 18,

welche ferner eine Modellierungseinrichtung (24) zum spektralabschnittsweisen Modellieren der zeitlichen Verdeckung des Audiotestsignals (14) und des Audioreferenzsignals (12) aufweist.

### 20. Vorrichtung nach Anspruch 19,

bei der die Modellierungseinrichtung (24) eine Integrationseinrichtung zum spektralabschnittsweisen Integrieren eines Audioreferenzteilsignals oder eines Audiotestteilsignals zur Berücksichtigung der Vorverdeckung und eine Dämpfungseinrichtung zum spektralabschnittsweisen exponentiellen Dämpfen des Audioreferenzteilsignals oder des Audiotestteilsignals zur Berücksichtigung der Nachverdeckung aufweist.

### 21. Vorrichtung nach einem der Ansprüche 18 bis 20,

Mehrzahl von Gruppenauswertungseine die ferner einrichtungen (56) zum gemeinsamen Auswerten nebeneinanderliegender Spektralabschnitte aufweist, um eine subjektive Empfindung des Codierungsfehlers des Audiotestsignals (14) zu erreichen, wobei die Anzahl der nebeneinanderliegenden ausgewerteten gemeinsam Spektralabschnitte derart gewählt ist, daß eine durch gemeinsam ausgewerteten Spektralabschnitte bildete Bandbreite kleiner oder gleich einer psychoakustischen Frequenzgruppe ist.

WO 98/23130 PCT/EP97/05446

22. Vorrichtung nach einem der Ansprüche 18 bis 21,

die ferner eine Globalauswertungseinrichtung (54) zum gemeinsamen Auswerten aller Spektralabschnitte aufweist, um eine globale Darstellung des Codierungsfehlers des Audiotestsignals (14) zu erreichen.

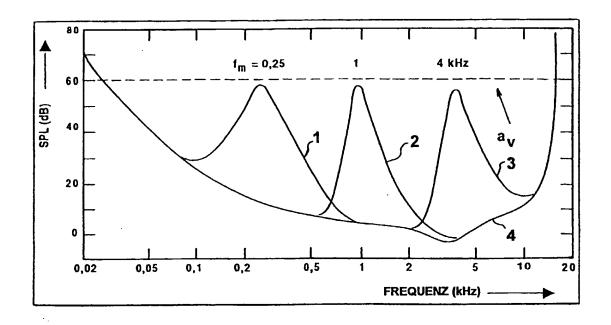


FIG.1

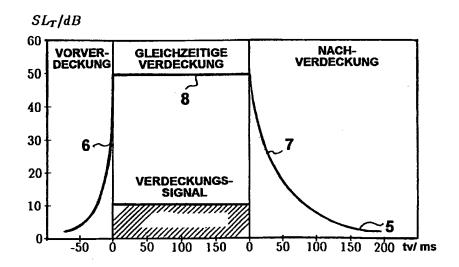


FIG.2

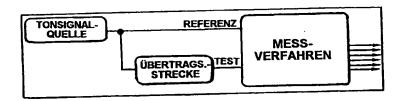


FIG.3

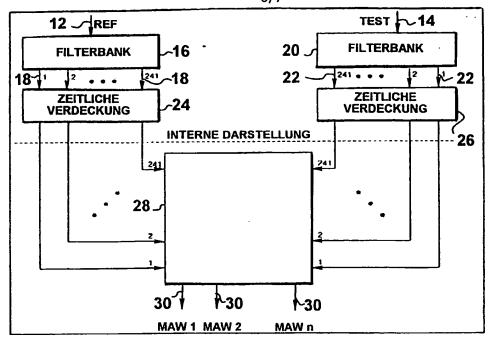


FIG.4

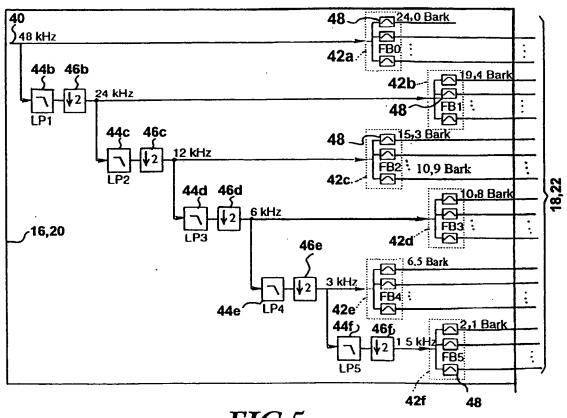


FIG.5

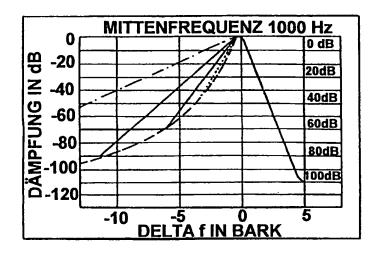


FIG.6

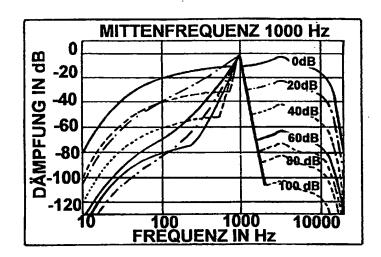


FIG.7

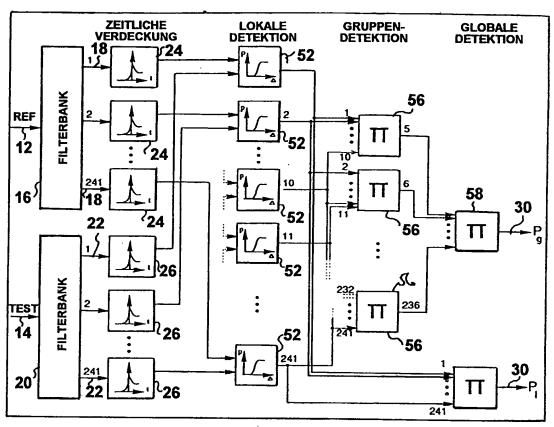


FIG.8

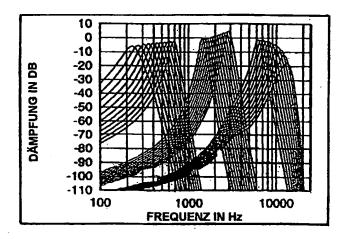


FIG.9

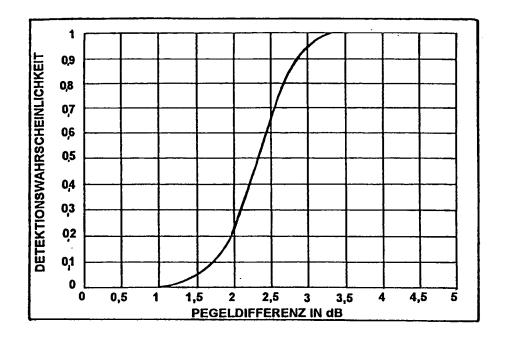


FIG.10

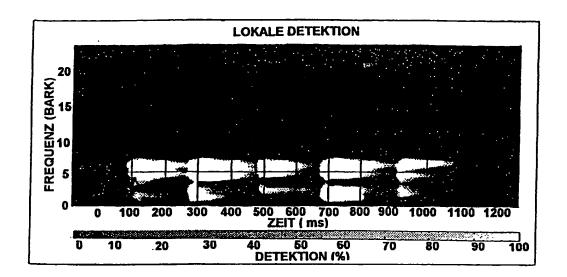


FIG.11

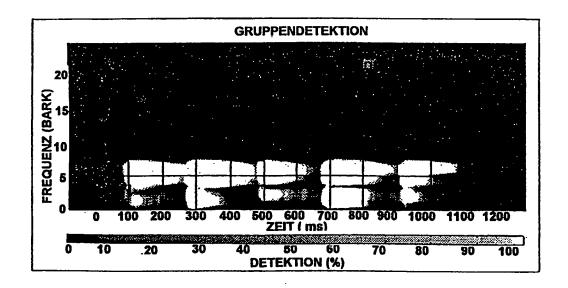


FIG.12

### INTERNATIONAL SEARCH REPORT

Inter anal Application No PCT/EP 97/05446

. CLASSIFICATION OF SUBJECT MATTER PC 6 H04S1/00 H04R29/00 IPC 6 According to International Patent Classification (IPC) or to both national classification and IPC B. FIELDS SEARCHED Minimum documentation searched (classification system followed by classification symbols) IPC 6 HO4S HO4R HO4B GO1R GO1H G10L Documentation searched other than minimum documentation to the extent that such documents are included in the fields searched Electronic data base consulted during the international search (name of data base and, where practical, search terms used) C. DOCUMENTS CONSIDERED TO BE RELEVANT Citation of document, with indication, where appropriate, of the relevant passages Relevant to claim No. Υ DE 42 22 050 A (HEAD ACOUSTIC) 14 January 1-3,6,1993 18,19, 21,22 A see column 1, line 6-11 4,5,7-9 15,17,20 see column 2, line 9-15 see column 3, line 42 - column 4, line 3 see column 4, line 24 - column 6, line 31 EP 0 553 538 A (ERICSSON) 4 August 1993 1-3,6,18,19, 21,22 A see page 2, line 17-40 7-13,15, 16,20 see page 3, line 9-24 see page 4, line 5 - page 5, line 56 Further documents are listed in the continuation of box C. Patent family members are listed in annex. Special categories of cited documents: 'T" later document published after the international filing date or priority date and not in conflict with the application but cited to understand the principle or theory underlying the "A" document defining the general state of the art which is not considered to be of particular relevance invention "E" earlier document but published on or after the international "X" document of particular relevance; the claimed invention cannot be considered novel or cannot be considered to involve an inventive step when the document is taken alone "L" document which may throw doubts on priority claim(s) or which is cited to establish the publicationdate of another citation or other special reason (as specified) document of particular relevance; the claimed invention cannot be considered to involve an inventive step when the document is combined with one or more other such docu-"O" document referring to an oral disclosure, use, exhibition or ments, such combination being obvious to a person skilled document published prior to the international filing date but in the art later than the priority date claimed "&" document member of the same patent family Date of the actual completion of theinternational search Date of mailing of the international search report 12 February 1998 19/02/1998 Name and mading address of the ISA Authorized officer European Patent Office, P.B. 5818 Patentiaan 2 NL - 2280 HV Rijswijk Tel. (+31-70) 340-2040, Tx. 31 651 epo ni, Zanti, P Fax: (+31-70) 340-3016

# INTERNATIONAL SEARCH REPORT

Inter anal Application No PCT/EP 97/05446

	· · · · · · · · · · · · · · · · · · ·	PCI/EP 9//05446	
	ation) DOCUMENTS CONSIDERED TO BE RELEVANT		
Category 3	Citation of document, with indication, where appropriate, of the relevant passages	Relevant to claim No.	
A	DE 43 45 171 A (FRAUNHOFER) 16 March 1995 see column 2, line 24-45 see column 3, line 16 - column 5, line 37 see column 6, line 2-47	1-22	
<b>A</b> .	DE 44 37 287 A (FRAUNHOFER) 2 May 1996 cited in the application	1,3-6, 10,11, 15-19, 21,22	
	see column 2, line 20 - column 4, line 11	21,22	
A	EP 0 473 367 A (SONY) 4 March 1992	1-7,18, 19	
	see column 1, line 24-58 see column 3, line 3 - column 11, line 48		
	,		
1			
ı			
	·		

## INTERNATIONAL SEARCH REPORT

· Information on patent family members

Inte. anal Application No
PCT/EP 97/05446

Patent document cited in search report	Publication date	Patent family member(s)	Publication date	
DE 4222050 A	14-01-93	NONE	<del></del>	
EP 553538 A	04-08-93	US 5384793 A	24-01-95	
DE 4345171 A	16-03-95	DE 4331376 C	10-11-94	
		AT 152871 T	15-05-97	
		AU 678270 B	22-05-97	
		AU 7187994 A	03-04-95	
		CA 2161263 A	23-03-95	
		DE 59402680 D	12-06-97	
		WO 9508227 A	23-03-95	
	•	EP 0719483 A	03-07-96	
		JP 8507424 T	06-08-96	
DE 4437287 A	02-05-96	AU 3805395 A	06-05-96	
		CA 2203008 A	25-04-96	
		WO 9612384 A	25-04-96	
		EP 0787416 A	06-08-97	
EP 473367 A	04-03-92	JP 4104617 A	07-04-92	
		CA 2049786 A	25-02-92	
		DE 69116476 D	29-02-96	
		DE 69116476 T	05-06-96	
		US 5260980 A	09-11-93	

#### INTERNATIONALER RECHERCHENBERICHT

Inte onales Aktenzeichen PCT/EP 97/05446

PCT/EP 97/05446 KLASSIFIZIERUNG DES ANMELDUNGSGEGENSTANDES PK 6 H04S1/00 H04R29/00 Nach der Internationalen Patentklassifikation (IPK) oder nach der nationalen Klassifikation und der IPK **B. RECHERCHIERTE GEBIETE** Recherchierter Mindestprüfstoff (Klassifikationssystem und Klassifikationssymbole) IPK 6 HO4S HO4R HO4B GO1R GO1H G10L Recherchierte aber nicht zum Mindestprüfstoff gehörende Veröffentlichungen, soweit diese unter die recherchierten Gebiete fallen Während der internationalen Recherche konsuttierte elektronische Datenbank (Name der Datenbank und evtl. verwendele Suchbegriffe) C. ALS WESENTLICH ANGESEHENE UNTERLAGEN Kategorie<sup>3</sup> Bezeichnung der Veröffentlichung, soweit erfordertich unter Angabe der in Betracht kommenden Teile Betr. Anspruch Nr. Y DE 42 22 050 A (HEAD ACOUSTIC) 14. Januar 1-3,6,1993 18,19, 21,22 siehe Spalte 1, Zeile 6-11 A 4,5,7-9, 15, 17, 20 siehe Spalte 2, Zeile 9-15 siehe Spalte 3, Zeile 42 - Spalte 4, Zeile siehe Spalte 4, Zeile 24 - Spalte 6, Zeile Y EP 0 553 538 A (ERICSSON) 4. August 1993 1-3,6,18,19, 21,22 siehe Seite 2, Zeile 17-40 A 7-13,15, 16.20 siehe Seite 3, Zeile 9-24 siehe Seite 4, Zeile 5 - Seite 5, Zeile 56 Weitere Veröffentlichungen sind der Fortsetzung von Feld C. zu Χl Siehe Anhang Patentfamilie Besondere Kategorien von angegebenen Veröffentlichungen T<sup>\*</sup> Spätere Veröffertlichung, die nach deminternationalen Anmeldedatum oder dem Prioritätsdatum veröffentlicht worden ist und mit der Anmeldung nicht kollidiert, sondern nur zum Verständnis des der "A" Veröffentlichung, die den allgemeinen Stand der Technik definiert, aber nicht als besonders bedeutsam anzusehen ist Erfindung zugrundeliegenden Prinzips oder der ihr zugrundeliegenden Theorie angegeben ist "E" älteres Dokument, das jedoch erst am oder nach dem internationalen Anmeldedatum veröffentlicht worden ist "X" Veröffertlichung von besonderer Bedeutung; die beanspruchte Erfindung kann allein aufgrund dieser Veröffertlichung nicht als neu oder auf erfinderischer Tätigkeit beruhend betrachtet werden "L" Veröffentlichung, die geeignet ist, einen Prioritätsanspruch zweitelhaft erscheinen zu lassen, oder durch die das Veröffentlichungsdatum eine scheinen zu lassen, oder durch die das verdrenindeningsdamm einer anderen im Recherchenbenkth genannten Veröffertlichung belegt werden "vooll oder die aus einem anderen besonderen Grund angegeben ist (wie Veröffentlichung von besonderer Bedeutung; die beanspruchte Erfindung kann nicht als auf erfinderischer Tätigkeit beruhend betrachtet werden, wenn die Veröffentlichung mit einer oder mehreren anderen "O" Veröffentlichung, die sich auf eine mündliche Offenbarung, eine Benutzung, eine Ausstellung oder andere Maßnahmen bezieht "P" Veröffentlichung, die vor dem internationalen Anneckedatum, aber nach dem beanspruchten Prioritätsdatum veröffentlicht worden ist Veröffentlichungen dieser Kategorie in Verbindung gebracht wird und diese Verbindung für einen Fachmann naheliegend ist "&" Veröffentlichung, die Mitglied derselben Patentfamilie ist Absendedatum des internationalen Recherchenberichts Datum des Abschlusses der internationalen Recherche 12.Februar 1998 19/02/1998 Name und Postanschrift der Internationalen Recherchenbehörde Bevollmächtigter Bediensteter Europäisches Patentamt. P.B. 5818 Patentlaan 2 NL - 2280 HV Rijswijk Tel. (+31-70) 340-2040, Tx. 31 651 epo nl, Zanti, P Fax: (+31-70) 340-3016

## INTERNATIONALER RECHERCHENBERICHT

Inter angles Aktenzeichen
PCT/EP 97/05446

		97/05446				
C.(Fortsetzung) ALS WESENTLICH ANGESEHENE UNTERLAGEN						
Kategorie*	Bezeichnung der Veröffentlichung, soweit erfordertich unter Angabe der in Betracht kommenden Teile	Betr. Anspruch Nr.				
Α	DE 43 45 171 A (FRAUNHOFER) 16.März 1995 siehe Spalte 2, Zeile 24-45 siehe Spalte 3, Zeile 16 - Spalte 5, Zeile 37 siehe Spalte 6, Zeile 2-47	1-22				
A	DE 44 37 287 A (FRAUNHOFER) 2.Mai 1996 in der Anmeldung erwähnt	1,3-6, 10,11, 15-19,				
	siehe Spalte 2, Zeile 20 - Spalte 4, Zeile 11	21,22				
A	EP 0 473 367 A (SONY) 4.Mārz 1992	1-7,18, 19				
	siehe Spalte 1, Zeile 24-58 siehe Spalte 3, Zeile 3 - Spalte 11, Zeile 48					
		·				

### INTERNATIONALER RECHERCHENBERICHT

Angaben zu Veröffentlichungen, die zur selben Patentfamilie gehören

Ints males Aktenzeichen
PCT/EP 97/05446

Im Recherchenbericht Ingeführtes Patentdokument			Datum der Veröffentlichung	Mitglied(er) der Patentfamilie	Datum der Veröffentlichung
DE	4222050	A	14-01-93	KEINE	
EP	553538	Α	04-08-93	US 5384793 A	24-01-95
DE	4345171	Α	16-03 <b>-</b> 95	DE 4331376 C	 10-11-94
				AT 152871 T	15-05-97
			•	AU 678270 B	22-05-97
				AU 7187994 A	03-04-95
				CA 2161263 A	23-03-95
				DE 59402680 D	12-06-97
				WO 9508227 A	23-03-95
				EP 0719483 A	03-07-96
				JP 8507424 T	06-08-96
DE	4437287	Α	02-05-96	AU 3805395 A	06-05-96
				CA 2203008 A	25-04-96
				WO 9612384 A	25-04-96
				EP 0787416 A	06-08-97
EP	473367	A	04-03-92	JP 4104617 A	07-04-92
				CA 2049786 A	25-02-92
				DE 69116476 D	29-02-96
				DE 69116476 T	05-06-96
				US 5260980 A	09-11-93